

# *Multivariate Statistical Analysis*

# 多元统计分析

2026年4月9日

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.1 分布函数与密度函数

- ▶ 累积分布函数 (cdf) 的定义为  $F(\mathbf{x}) = \mathbb{P}(X < \mathbf{x})$ .

- ▶ 如果概率密度函数 (pdf) 存在, 则  $F(\mathbf{x}) = \int_{-\infty}^{\mathbf{x}} f(\mathbf{u}) d\mathbf{u}$ .

- ▶ 概率密度函数 (pdf) 满足  $\int_{-\infty}^{\infty} f(\mathbf{x}) d\mathbf{x} = 1$ .

- ▶ 将随机向量  $X$  分块为  $X = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix}$ , 设  $X_1$  与  $X_2$  的联合 (即  $X$  的) 分布函数为  $F$ , 则  $X_1$  的边

际分布函数为  $F_{X_1}(\mathbf{x}_1) = \mathbb{P}(X_1 < \mathbf{x}_1)$ ,  $X_1$  的边际概率密度函数显然为

$f_{X_1}(\mathbf{x}_1) = \int_{-\infty}^{\infty} f(\mathbf{x}_1, \mathbf{x}_2) d\mathbf{x}_2$ . 对联合概率密度函数求导亦可得到相同的边际概率密度函数.

- ▶ 给定  $X_1 = \mathbf{x}_1$  时  $X_2$  条件概率密度函数为  $f(\mathbf{x}_2 | \mathbf{x}_1) = \frac{f(\mathbf{x}_1, \mathbf{x}_2)}{f_{X_1}(\mathbf{x}_1)}$ .

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.1 分布函数与密度函数

- ▶ 两个随机向量  $\mathbf{X}_1$  与  $\mathbf{X}_2$  独立, 当且仅当  $f(\mathbf{x}_1, \mathbf{x}_2) = f_{\mathbf{X}_1}(\mathbf{x}_1) \cdot f_{\mathbf{X}_2}(\mathbf{x}_2)$ , 也等价于  $f(\mathbf{x}_2 | \mathbf{x}_1) = f_{\mathbf{X}_2}(\mathbf{x}_2)$ .
- ▶ 不同的联合概率密度函数可以有相同的边际概率密度函数.
- ▶ **连接 (copula)** 是将边际分布函数联系起来以形成联合分布函数的一个函数.

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.2 矩与特征函数

- ▶ 随机向量  $X$  的期望为  $\mu = \int x f(x) dx$ , 协方差矩阵为  $\Sigma = \text{Var}(X) = \mathbb{E} \left[ (X - \mu)(X - \mu)^T \right]$ , 将其记为  $X \sim (\mu, \Sigma)$ .
- ▶ 求期望是线性运算, 即  $\mathbb{E}(\alpha X + \beta Y) = \alpha \mathbb{E}(X) + \beta \mathbb{E}(Y)$ . 如果  $X$  与  $Y$  相互独立, 则  $\mathbb{E}(XY^T) = \mathbb{E}(X) \mathbb{E}(Y^T)$ .
- ▶ 两个随机向量  $X$  与  $Y$  的协方差矩阵为
$$\Sigma_{XY} = \text{Cov}(X, Y) = \mathbb{E} \left[ (X - \mathbb{E}(X))(Y - \mathbb{E}(Y))^T \right] = \mathbb{E}(XY^T) - \mathbb{E}(X) \mathbb{E}(Y^T).$$
如果  $X$  与  $Y$  独立, 则  $\text{Cov}(X, Y) = 0$ .
- ▶ 随机向量  $X$  的特征函数 (cf) 为  $\varphi_X(t) = \mathbb{E} \left( e^{it^T X} \right)$ .
- ▶  $p$  维随机向量  $X$  的分布完全由形如  $t^T X$  的所有一维分布确定, 其中  $t \in \mathbb{R}^p$  (Cramer-Wold 定理).
- ▶ 条件期望  $\mathbb{E}(X_2 | X_1)$  是用  $X_1$  的一个函数对  $X_2$  在均方误差 (MSE) 意义下的最佳近似.

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.3 变换

- ▶ 如果  $X$  的密度函数为  $f_X(\mathbf{x})$ , 设  $X = u(Y)$ , 则变换后的随机向量  $Y$  的概率密度函数为

$$f_Y(\mathbf{y}) = \text{abs}(|\mathcal{J}|) \cdot f_X[u(\mathbf{y})], \text{ 其中 } \mathcal{J} \text{ 表示变换的 Jacobian 矩阵 } \mathcal{J} = \left( \frac{\partial u(y_i)}{\partial y_j} \right).$$

- ▶ 对于线性关系  $Y = \mathcal{A}X + \mathbf{b}$  的情形,  $X$  与  $Y$  的概率密度函数之间的关系为

$$f_Y(\mathbf{y}) = \text{abs}(|\mathcal{A}|^{-1}) \cdot f_X\{\mathcal{A}^{-1}(\mathbf{y} - \mathbf{b})\}.$$

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.4 多元正态分布

- ▶  $p$  维正态分布  $X \sim N_p(\boldsymbol{\mu}, \Sigma)$  的概率密度函数为

$$f(\mathbf{x}) = |2\pi\Sigma|^{-1/2} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\}.$$

多元正态分布的密度函数的等高线是椭球面，其半轴的长度与  $\sqrt{\lambda_i}$  成比例，其中  $\lambda_i$  表示  $\Sigma$  的特征值 ( $i = 1, 2, \dots, p$ ).

- ▶ 设  $X \sim N_p(\boldsymbol{\mu}, \Sigma)$ ，经 Mahalanobis 变换有  $Y = \Sigma^{-1/2} (X - \boldsymbol{\mu}) \sim N_p(\mathbf{0}, \mathcal{I}_p)$ . 反之，我们可以由  $Y \sim N_p(\mathbf{0}, \mathcal{I}_p)$  经过变换  $X = \Sigma^{1/2} Y + \boldsymbol{\mu}$  得到  $X \sim N_p(\boldsymbol{\mu}, \Sigma)$ .

- ▶ 如果协方差矩阵  $\Sigma$  是奇异矩阵 (即,  $\text{rank}(\Sigma) < p$ ), 则它定义了一个奇异正态分布.

- ▶ 奇异正态分布的密度函数为  $\frac{(2\pi)^{-k/2}}{(\lambda_1 \lambda_2 \cdots \lambda_k)^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-} (\mathbf{x} - \boldsymbol{\mu}) \right\}$ .

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.5 抽样分布与中心极限定理

- ▶ 设  $X_1, X_2, \dots, X_n$  是独立同分布的随机向量, 且  $X_i \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , 则  $\bar{\boldsymbol{x}} \sim N_p\left(\boldsymbol{\mu}, \frac{1}{n}\boldsymbol{\Sigma}\right)$ .
- ▶ 设  $X_1, X_2, \dots, X_n$  是独立同分布的随机向量, 且  $X_i \sim (\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , 则  $\sqrt{n}(\bar{\boldsymbol{x}} - \boldsymbol{\mu})$  的分布渐进服从  $N(\mathbf{0}, \boldsymbol{\Sigma})$  (中心极限定理).
- ▶ 设  $X_1, X_2, \dots, X_n$  是独立同分布的随机变量, 且  $X_i \sim (\mu, \sigma)$ , 则由中心极限定理可得  $\mu$  的渐进置信区间为:  $\bar{x} \pm \frac{\hat{\sigma}}{\sqrt{n}} u_{\frac{\alpha}{2}}$ .
- ▶ 如果  $t$  是一个渐进服从正态分布的统计量, 即,  $\sqrt{n}(t - \mu) \xrightarrow{\mathcal{L}} N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , 则该结论对函数  $f(t)$  也成立, 即,  $\sqrt{n}\{f(t) - f(\boldsymbol{\mu})\}$  也渐进服从正态分布.

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ 厚尾：尾部面积相比同均值  $\mu$ 、同方差  $\sigma^2$  的正态分布有更高的概率。厚尾分布的峰度大于3。
- ▶ 广义双曲分布 (一维)

$$f_{\text{GH}}(x; \lambda, \alpha, \beta, \delta, \mu) = \frac{\left(\frac{\sqrt{\alpha^2 - \beta^2}}{\delta}\right)^\lambda}{\sqrt{2\pi} K_\lambda(\delta \sqrt{\alpha^2 - \beta^2})} \cdot \frac{K_{\lambda-1/2}\left[\alpha \sqrt{\delta^2 + (x - \mu)^2}\right]}{\left(\frac{\sqrt{\delta^2 + (x - \mu)^2}}{\alpha}\right)^{1/2-\lambda}} \cdot e^{\beta(x-\mu)}$$

$$K_\lambda(x) = \frac{1}{2} \int_0^\infty y^{\lambda-1} e^{-\frac{x}{2}(y+y^{-1})} dy, \quad \text{修正的指数为 } \lambda \text{ 第三类贝塞尔 (Bessel) 函数}$$

$$\text{参数的取值范围: } \begin{cases} \mu \in \mathbb{R} \\ \delta \geq 0, \quad |\beta| < \alpha, \quad \text{if } \lambda > 0 \\ \delta > 0, \quad |\beta| < \alpha, \quad \text{if } \lambda = 0 \\ \delta \geq 0, \quad |\beta| \leq \alpha, \quad \text{if } \lambda < 0 \end{cases}$$

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ 厚尾：尾部面积相比同均值  $\mu$ 、同方差  $\sigma^2$  的正态分布有更高的概率。厚尾分布的峰度大于3。
- ▶ 广义双曲分布 (一维)

$$f_{\text{GH}}(x; \lambda, \alpha, \beta, \delta, \mu) = \frac{\left(\frac{\sqrt{\alpha^2 - \beta^2}}{\delta}\right)^\lambda}{\sqrt{2\pi} K_\lambda(\delta \sqrt{\alpha^2 - \beta^2})} \cdot \frac{K_{\lambda-1/2}\left[\alpha \sqrt{\delta^2 + (x - \mu)^2}\right]}{\left(\frac{\sqrt{\delta^2 + (x - \mu)^2}}{\alpha}\right)^{1/2-\lambda}} \cdot e^{\beta(x-\mu)}$$

$$E(X) = \mu + \frac{\delta \beta}{\sqrt{\alpha^2 - \beta^2}} \cdot \frac{K_{\lambda+1}(\delta \sqrt{\alpha^2 - \beta^2})}{K_\lambda(\delta \sqrt{\alpha^2 - \beta^2})}$$

$$\text{Var}(X) = \delta^2 \left\{ \frac{K_{\lambda+1}(\delta \sqrt{\alpha^2 - \beta^2})}{\delta \sqrt{\alpha^2 - \beta^2} K_\lambda(\delta \sqrt{\alpha^2 - \beta^2})} + \frac{\beta^2}{\alpha^2 - \beta^2} \left[ \frac{K_{\lambda+2}(\delta \sqrt{\alpha^2 - \beta^2})}{K_\lambda(\delta \sqrt{\alpha^2 - \beta^2})} - \left( \frac{K_{\lambda+1}(\delta \sqrt{\alpha^2 - \beta^2})}{K_\lambda(\delta \sqrt{\alpha^2 - \beta^2})} \right)^2 \right] \right\}$$

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ 厚尾：尾部面积相比同均值  $\mu$ 、同方差  $\sigma^2$  的正态分布有更高的概率。厚尾分布的峰度大于3。
- ▶ 广义双曲分布 (一维)

$$f_{\text{GH}}(x; \lambda, \alpha, \beta, \delta, \mu) = \frac{\left(\frac{\sqrt{\alpha^2 - \beta^2}}{\delta}\right)^\lambda}{\sqrt{2\pi} K_\lambda(\delta \sqrt{\alpha^2 - \beta^2})} \cdot \frac{K_{\lambda-1/2}\left[\alpha \sqrt{\delta^2 + (x - \mu)^2}\right]}{\left(\frac{\sqrt{\delta^2 + (x - \mu)^2}}{\alpha}\right)^{1/2-\lambda}} \cdot e^{\beta(x-\mu)}$$

当  $\lambda = 1$  时，得到双曲 (HYP) 分布

$$f_{\text{HYP}}(x; \alpha, \beta, \delta, \mu) = \frac{\sqrt{\alpha^2 - \beta^2}}{2\alpha\delta K_1(\delta \sqrt{\alpha^2 - \beta^2})} e^{-\alpha \sqrt{\delta^2 + (x - \mu)^2} + \beta(x-\mu)}, \quad x, \mu \in \mathbb{R}, \delta \geq 0, |\beta| < \alpha$$

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ 厚尾：尾部面积相比同均值  $\mu$ 、同方差  $\sigma^2$  的正态分布有更高的概率。厚尾分布的峰度大于3。
- ▶ 广义双曲分布 (一维)

$$f_{\text{GH}}(x; \lambda, \alpha, \beta, \delta, \mu) = \frac{\left(\frac{\sqrt{\alpha^2 - \beta^2}}{\delta}\right)^\lambda}{\sqrt{2\pi} K_\lambda(\delta \sqrt{\alpha^2 - \beta^2})} \cdot \frac{K_{\lambda-1/2}\left[\alpha \sqrt{\delta^2 + (x - \mu)^2}\right]}{\left(\frac{\sqrt{\delta^2 + (x - \mu)^2}}{\alpha}\right)^{1/2-\lambda}} \cdot e^{\beta(x-\mu)}$$

当  $\lambda = -\frac{1}{2}$  时，得到正态逆高斯 (NIG) 分布

$$f_{\text{NIG}}(x; \alpha, \beta, \delta, \mu) = \frac{\alpha\delta}{\pi} \frac{K_1\left(\alpha \sqrt{\delta^2 + (x - \mu)^2}\right)}{\sqrt{\delta^2 + (x - \mu)^2}} e^{\delta \sqrt{\alpha^2 - \beta^2} + \beta(x-\mu)}$$

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ 学生  $t$  分布：概率密度函数为

$$f_t(x; n) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n\pi} \Gamma\left(\frac{n}{2}\right)} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}, \quad -\infty < x < \infty$$

自由度  $\leftarrow$

$$\Gamma(\alpha) = \int_0^{\infty} x^{\alpha-1} e^{-x} dx$$

$$\text{均值 } \mu = 0$$

$$\text{方差 } \sigma^2 = \frac{n}{n-2}$$

$$\text{斜度} = 0$$

$$\text{峰度} = 3 + \frac{6}{n-4}$$

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ Laplace 分布：均值为  $\mu$ ，尺度参数为  $\theta$  的 Laplace 分布的概率密度函数为

$$f_{\text{Laplace}}(x; \mu, \theta) = \frac{1}{2\theta} e^{-\frac{|x-\mu|}{\theta}}, \quad -\infty < x < \infty$$

分布函数为

$$F_{\text{Laplace}}(x; \mu, \theta) = \frac{1}{2} \left[ 1 + \text{sign}(x - \mu) \left( 1 - e^{-\frac{|x-\mu|}{\theta}} \right) \right]$$

$$\text{sign}(x - \mu) = \begin{cases} 1, & x > \mu \\ 0, & x = \mu \\ -1, & x < \mu \end{cases}$$

均值  $\mu = \mu$

方差  $\sigma^2 = 2\theta^2$

斜度 = 0

峰度 = 6

标准 Laplace 分布：  $\mu = 0, \theta = 1$

$$f(x) = \frac{e^{-|x|}}{2}$$

$$F(x) = \begin{cases} \frac{e^x}{2}, & x < 0 \\ 1 - \frac{e^{-x}}{2}, & x \geq 0 \end{cases}$$

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ Cauchy 分布: 位置参数  $m$ , 尺度参数  $s$  的 Cauchy 分布的概率密度函数和分布函数分别为

$$f_{\text{Cauchy}}(x; m, s) = \frac{1}{s\pi} \cdot \frac{1}{1 + \left(\frac{x-m}{s}\right)^2}, \quad -\infty < x < \infty$$

$$F_{\text{Cauchy}}(x; m, s) = \frac{1}{2} + \frac{1}{\pi} \arctan\left(\frac{x-m}{s}\right)$$

- ▶ 标准 Cauchy 分布:  $m = 0, s = 1$

$$f_{\text{Cauchy}}(x) = \frac{1}{\pi(1+x^2)}, \quad -\infty < x < \infty$$

$$F_{\text{Cauchy}}(x) = \frac{1}{2} + \frac{\arctan x}{\pi}$$

- ▶ Cauchy 分布的均值、方差、斜度、峰度不存在.
- ▶ Cauchy 分布的众数 (mode) 和中位数存在, 都等于位置参数  $m$ .

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- 混合模型：由  $L$  个分布构成的**混合分布** (mixture distribution) 的概率密度函数可表示为

$$f(x) = \sum_{l=1}^L w_l \cdot p_l(x)$$

权重

约束条件：  $0 \leq w_l \leq 1$ ,  $\sum_{l=1}^L w_l = 1$ ,  $\int p_l(x) dx = 1$

$$\text{均值 } \mu = \sum_{l=1}^L w_l \mu_l$$

$$\text{方差 } \sigma^2 = \sum_{l=1}^L w_l \left[ \sigma_l^2 + (\mu_l - \mu)^2 \right]$$

$$\text{斜度} = \sum_{l=1}^L w_l \left[ \left( \frac{\sigma_l}{\sigma} \right)^3 SK_l + \frac{3\sigma_l^2 (\mu_l - \mu)}{\sigma^3} + \left( \frac{\mu_l - \mu}{\sigma} \right)^3 \right]$$

$$\text{峰度} = \sum_{l=1}^L w_l \left[ \left( \frac{\sigma_l}{\sigma} \right)^4 K_l + \frac{6(\mu_l - \mu)^2 \sigma_l^2}{\sigma^4} + \frac{4(\mu_l - \mu) \sigma_l^3}{\sigma^4} SK_l + \left( \frac{\mu_l - \mu}{\sigma} \right)^4 \right]$$

只要混合分布中密度函数的数量足够多，并且模型的参数选择正确的话，混合模型就能以任意的精度近似任何一个连续型的密度。

其中  $\mu_l$ 、 $\sigma_l$ 、 $SK_l$  以及  $K_l$  分别是分布  $p_l(x)$  的均值、方差、斜度和峰度。

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ 混合模型：正态 (高斯) 混合分布的概率密度函数为

$$f_{\text{GM}}(x) = \sum_{l=1}^L \frac{w_l}{\sqrt{2\pi} \sigma_l} e^{-\frac{(x-\mu_l)^2}{2\sigma_l^2}}$$

均值为 0 的正态分布构成的正态混合分布，其密度函数为

$$f_{\text{GM}}(x) = \sum_{l=1}^L \frac{w_l}{\sqrt{2\pi} \sigma_l} e^{-\frac{x^2}{2\sigma_l^2}}$$

$$\text{均值 } \mu = 0$$

$$\text{方差 } \sigma^2 = \sum_{l=1}^L w_l \sigma_l^2$$

$$\text{斜度} = 0$$

$$\text{峰度} = \sum_{l=1}^L w_l \left( \frac{\sigma_l}{\sigma} \right)^4 \cdot 3$$

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ 多元广义双曲分布：特征函数

$$\Phi(\mathbf{t}) = \left( \frac{\alpha^2 - \boldsymbol{\beta}^T \Delta \boldsymbol{\beta}}{\alpha^2 - \boldsymbol{\beta}^T \Delta \boldsymbol{\beta} + \frac{1}{2} \mathbf{t}^T \Delta \mathbf{t} - \mathbf{i} \boldsymbol{\beta}^T \Delta \mathbf{t}} \right)^{\frac{\lambda}{2}} \cdot \frac{K_{\lambda} \left( \delta \sqrt{\alpha^2 - \boldsymbol{\beta}^T \Delta \boldsymbol{\beta} + \frac{1}{2} \mathbf{t}^T \Delta \mathbf{t} - \mathbf{i} \boldsymbol{\beta}^T \Delta \mathbf{t}} \right)}{K_{\lambda} \left( \delta \sqrt{\alpha^2 - \boldsymbol{\beta}^T \Delta \boldsymbol{\beta}} \right)}$$

多元双曲 (HYP) 分布:  $\lambda = \frac{d+1}{2}$ .

多元正态逆高斯 (NIG) 分布:  $\lambda = -\frac{1}{2}$ .

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.6 厚尾分布

- ▶ 多元  $t$  分布：自由度为  $n$ 、非中心参数为  $\boldsymbol{\mu}$  的非中心  $t$  分布的概率密度函数为

$$f_t(\mathbf{t}; n, \Sigma, \boldsymbol{\mu}) = \frac{\Gamma\left(\frac{n+p}{2}\right)}{\Gamma\left(\frac{n}{2}\right) n^{\frac{p}{2}} \pi^{\frac{p}{2}} |\Sigma|^{\frac{1}{2}} \left[1 + \frac{1}{n}(\mathbf{t} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{t} - \boldsymbol{\mu})\right]^{\frac{n+p}{2}}}$$

- ▶ 多元 Laplace 分布：概率密度函数为

$$f_{MLaplace_d}(\mathbf{x}; \mathbf{m}, \Sigma) = \frac{2e^{\mathbf{x}^T \Sigma^{-1} \mathbf{m}}}{(2\pi)^{\frac{d}{2}} |\Sigma|^{\frac{1}{2}}} \left(\frac{\mathbf{x}^T \Sigma^{-1} \mathbf{x}}{2 + \mathbf{m}^T \Sigma^{-1} \mathbf{m}}\right)^{\frac{\lambda}{2}} K_{\lambda} \left(\sqrt{(2 + \mathbf{m}^T \Sigma^{-1} \mathbf{m}) (\mathbf{x}^T \Sigma^{-1} \mathbf{x})}\right)$$

$$K_{\lambda} = \frac{1}{2} \left(\frac{x}{2}\right)^{\lambda} \int_0^{\infty} t^{-\lambda-1} e^{-t-\frac{x^2}{4t}} dt, x > 0$$

$$\lambda = \frac{2-d}{2}$$

$$\begin{aligned} \mathbf{E}(\mathbf{X}) &= \mathbf{m} \\ \text{Var}(\mathbf{X}) &= \Sigma + \mathbf{m}\mathbf{m}^T \end{aligned}$$

- ▶ 多元正态混合分布的概率密度函数为

$$f(\mathbf{x}) = \sum_{l=1}^L \frac{w_l}{|2\pi\Sigma_l|^{\frac{1}{2}}} e^{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_l)^T \Sigma_l^{-1} (\mathbf{x} - \boldsymbol{\mu}_l)}$$

## 已学知识点 (Recap)

### 第 4 章 多元分布

#### 4.8 自助法

- ▶ 样本容量较小时，自助法可以提升置信区间的精度.
- ▶ 自助分布  $\mathcal{L} \left\{ \sqrt{n} \left( \frac{\bar{x}^* - \bar{x}}{\hat{\sigma}^*} \right) \right\}$  收敛于分布  $\mathcal{L} \left\{ \sqrt{n} \left( \frac{\bar{x}^* - \bar{x}}{\hat{\sigma}} \right) \right\}$  的渐进极限分布.

## Theory of the Multi-normal

# 多元正态分布的理论

## 概述

### 多元正态分布的理论

多元正态分布的基本性质

Wishart 分布

Hotelling's  $T^2$  分布

球形分布和椭圆分布

## 多元正态分布的基本性质

- 上一章已建立的性质

- ▶  $X \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  的概率密度函数为

$$f(\mathbf{x}) = |2\pi\boldsymbol{\Sigma}|^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}) \right\}$$

$$\mathbb{E}(\mathbf{X}) = \boldsymbol{\mu}$$

$$\text{Cov}(\mathbf{X}) = \mathbb{E} [(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^T] = \boldsymbol{\Sigma}$$

- ▶ 设  $X \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , 矩阵  $\mathcal{A}_{p \times p}$ , 向量  $\mathbf{c} \in \mathbb{R}^p$ , 则

$$\mathbf{Y} = \mathcal{A}\mathbf{X} + \mathbf{c} \sim N_p(\mathcal{A}\boldsymbol{\mu} + \mathbf{c}, \mathcal{A}\boldsymbol{\Sigma}\mathcal{A}^T)$$

- ▶ 设  $X \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , 经 Mahalanobis 变换则有

$$\mathbf{Y} = \boldsymbol{\Sigma}^{-1/2}(\mathbf{X} - \boldsymbol{\mu}) \sim N_p(\mathbf{0}, \mathcal{I}_p),$$

且有

$$\mathbf{Y}^T \mathbf{Y} = (\mathbf{X} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{X} - \boldsymbol{\mu}) \sim \chi_p^2$$

## 多元正态分布的基本性质

**定理 5.1** 设  $X = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ ,  $X_1 \in \mathbb{R}^r$ ,  $X_2 \in \mathbb{R}^{p-r}$ . 利用协方差矩阵的分块

$$\boldsymbol{\Sigma} = \begin{pmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{21} & \boldsymbol{\Sigma}_{22} \end{pmatrix}$$

定义

$$X_{2.1} = X_2 - \boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}X_1$$

则

$$X_1 \sim N_r(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_{11})$$

$$X_{2.1} \sim N_{p-r}(\boldsymbol{\mu}_{2.1}, \boldsymbol{\Sigma}_{22.1})$$

相互独立, 其中

$$\boldsymbol{\mu}_{2.1} = \boldsymbol{\mu}_2 - \boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}\boldsymbol{\mu}_1, \quad \boldsymbol{\Sigma}_{22.1} = \boldsymbol{\Sigma}_{22} - \boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}\boldsymbol{\Sigma}_{12}$$

# 多元正态分布的基本性质

证明: 记  $\mathcal{A} = (\mathcal{I}_r, \mathbf{0})$ ,  $\mathcal{B} = (-\Sigma_{21}\Sigma_{11}^{-1}, \mathcal{I}_{p-r})$ ,

$$\mathbf{X}_1 = (\mathcal{I}_r, \mathbf{0}) \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{pmatrix} = \mathcal{A} \mathbf{X}$$

$$\begin{aligned} \mathbf{X}_{2.1} &= \mathbf{X}_2 - \Sigma_{21}\Sigma_{11}^{-1}\mathbf{X}_1 \\ &= \begin{pmatrix} -\Sigma_{21}\Sigma_{11}^{-1} & \mathcal{I}_{p-r} \end{pmatrix} \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{pmatrix} \\ &= \mathcal{B} \mathbf{X} \end{aligned}$$

则  $\mathbf{X}_1$  与  $\mathbf{X}_{2.1}$  均服从正态分布.

$$\begin{aligned} \text{Cov}(\mathbf{X}_1, \mathbf{X}_{2.1}) &= \mathcal{A}\Sigma\mathcal{B}^T = (\mathcal{I}_r \quad \mathbf{0}) \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix} \begin{pmatrix} -\Sigma_{21}\Sigma_{11}^{-1} & \mathcal{I}_{p-r} \end{pmatrix}^T \\ &= (\Sigma_{11} \quad \Sigma_{12}) \begin{pmatrix} (-\Sigma_{21}\Sigma_{11}^{-1})^T \\ \mathcal{I}_{p-r} \end{pmatrix} = (\Sigma_{11} \quad \Sigma_{12}) \begin{pmatrix} -(\Sigma_{11}^{-1})^T \Sigma_{21}^T \\ \mathcal{I}_{p-r} \end{pmatrix} = (\Sigma_{11} \quad \Sigma_{12}) \begin{pmatrix} -\Sigma_{11}^{-1}\Sigma_{12} \\ \mathcal{I}_{p-r} \end{pmatrix} \end{aligned}$$

$$= -\Sigma_{11}\Sigma_{11}^{-1}\Sigma_{12} + \Sigma_{12} \equiv \mathbf{0} \quad \Rightarrow \quad \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_{2.1} \end{pmatrix} = \begin{pmatrix} \mathcal{A} \mathbf{X} \\ \mathcal{B} \mathbf{X} \end{pmatrix} = \begin{pmatrix} \mathcal{A} \\ \mathcal{B} \end{pmatrix} \mathbf{X} \sim N_p \left( \begin{pmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_{2.1} \end{pmatrix}, \begin{pmatrix} \Sigma_{11} & \mathbf{0} \\ \mathbf{0} & \Sigma_{22.1} \end{pmatrix} \right)$$

定理 5.1 设  $\mathbf{X} = \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{pmatrix} \sim N_p(\boldsymbol{\mu}, \Sigma)$ ,  $\mathbf{X}_1 \in \mathbb{R}^r$ ,  $\mathbf{X}_2 \in \mathbb{R}^{p-r}$ . 利用协方差矩阵的分块

$$\Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}$$

定义

$$\mathbf{X}_{2.1} = \mathbf{X}_2 - \Sigma_{21}\Sigma_{11}^{-1}\mathbf{X}_1$$

则

$$\mathbf{X}_1 \sim N_r(\boldsymbol{\mu}_1, \Sigma_{11})$$

$$\mathbf{X}_{2.1} \sim N_{p-r}(\boldsymbol{\mu}_{2.1}, \Sigma_{22.1})$$

相互独立, 其中

$$\boldsymbol{\mu}_{2.1} = \boldsymbol{\mu}_2 - \Sigma_{21}\Sigma_{11}^{-1}\boldsymbol{\mu}_1, \quad \Sigma_{22.1} = \Sigma_{22} - \Sigma_{21}\Sigma_{11}^{-1}\Sigma_{12}$$

▶ 设  $\mathbf{X} \sim N_p(\boldsymbol{\mu}, \Sigma)$ , 矩阵  $\mathcal{A}_{p \times p}$ , 向量  $\mathbf{c} \in \mathbb{R}^p$ , 则

$$\mathbf{Y} = \mathcal{A}\mathbf{X} + \mathbf{c} \sim N_p(\mathcal{A}\boldsymbol{\mu} + \mathbf{c}, \mathcal{A}\Sigma\mathcal{A}^T)$$

## 多元正态分布的基本性质

证明: 
$$\begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_{2.1} \end{pmatrix} = \begin{pmatrix} \mathcal{A} \\ \mathcal{B} \end{pmatrix} \mathbf{X} \sim N_p \left( \begin{pmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_{2.1} \end{pmatrix}, \begin{pmatrix} \boldsymbol{\Sigma}_{11} & \mathbf{0} \\ \mathbf{0} & \boldsymbol{\Sigma}_{22.1} \end{pmatrix} \right)$$

▶  $\mathbf{X} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  的概率密度函数为

$$f(\mathbf{x}) = |2\pi\boldsymbol{\Sigma}|^{-\frac{1}{2}} \exp \left\{ -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}) \right\}$$

$$f(\mathbf{x}_1, \mathbf{x}_{2.1}) = \left| 2\pi \begin{pmatrix} \boldsymbol{\Sigma}_{11} & \mathbf{0} \\ \mathbf{0} & \boldsymbol{\Sigma}_{22.1} \end{pmatrix} \right|^{-1/2} \exp \left\{ -\frac{1}{2} \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_{2.1} \end{bmatrix} - \begin{pmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_{2.1} \end{pmatrix} \right\}^T \begin{pmatrix} \boldsymbol{\Sigma}_{11} & \mathbf{0} \\ \mathbf{0} & \boldsymbol{\Sigma}_{22.1} \end{pmatrix}^{-1} \begin{bmatrix} \mathbf{x}_1 \\ \mathbf{x}_{2.1} \end{bmatrix} - \begin{pmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_{2.1} \end{pmatrix} \right\}$$

$$= |2\pi\boldsymbol{\Sigma}_{11}|^{-1/2} \cdot |2\pi\boldsymbol{\Sigma}_{22.1}|^{-1/2} \exp \left\{ -\frac{1}{2} \begin{pmatrix} \mathbf{x}_1 - \boldsymbol{\mu}_1 \\ \mathbf{x}_{2.1} - \boldsymbol{\mu}_{2.1} \end{pmatrix}^T \begin{pmatrix} \boldsymbol{\Sigma}_{11}^{-1} & \mathbf{0} \\ \mathbf{0} & \boldsymbol{\Sigma}_{22.1}^{-1} \end{pmatrix} \begin{pmatrix} \mathbf{x}_1 - \boldsymbol{\mu}_1 \\ \mathbf{x}_{2.1} - \boldsymbol{\mu}_{2.1} \end{pmatrix} \right\}$$

$$= |2\pi\boldsymbol{\Sigma}_{11}|^{-1/2} \cdot |2\pi\boldsymbol{\Sigma}_{22.1}|^{-1/2} \exp \left\{ -\frac{1}{2} \begin{bmatrix} (\mathbf{x}_1 - \boldsymbol{\mu}_1)^T & (\mathbf{x}_{2.1} - \boldsymbol{\mu}_{2.1})^T \end{bmatrix} \begin{bmatrix} \boldsymbol{\Sigma}_{11}^{-1} (\mathbf{x}_1 - \boldsymbol{\mu}_1) \\ \boldsymbol{\Sigma}_{22.1}^{-1} (\mathbf{x}_{2.1} - \boldsymbol{\mu}_{2.1}) \end{bmatrix} \right\}$$

$$= |2\pi\boldsymbol{\Sigma}_{11}|^{-1/2} \cdot |2\pi\boldsymbol{\Sigma}_{22.1}|^{-1/2} \exp \left\{ -\frac{1}{2} \left[ (\mathbf{x}_1 - \boldsymbol{\mu}_1)^T \boldsymbol{\Sigma}_{11}^{-1} (\mathbf{x}_1 - \boldsymbol{\mu}_1) + (\mathbf{x}_{2.1} - \boldsymbol{\mu}_{2.1}) \boldsymbol{\Sigma}_{22.1}^{-1} (\mathbf{x}_{2.1} - \boldsymbol{\mu}_{2.1}) \right] \right\}$$

$$= |2\pi\boldsymbol{\Sigma}_{11}|^{-1/2} \exp \left\{ -\frac{1}{2} (\mathbf{x}_1 - \boldsymbol{\mu}_1)^T \boldsymbol{\Sigma}_{11}^{-1} (\mathbf{x}_1 - \boldsymbol{\mu}_1) \right\} \cdot f_{\mathbf{X}_1}(\mathbf{x}_1)$$

$$|2\pi\boldsymbol{\Sigma}_{22.1}|^{-1/2} \exp \left\{ -\frac{1}{2} (\mathbf{x}_{2.1} - \boldsymbol{\mu}_{2.1}) \boldsymbol{\Sigma}_{22.1}^{-1} (\mathbf{x}_{2.1} - \boldsymbol{\mu}_{2.1}) \right\} = f_{\mathbf{X}_{2.1}}(\mathbf{x}_{2.1})$$

$\mathbf{X}_1$  与  $\mathbf{X}_{2.1}$  相互独立

## 多元正态分布的基本性质

**推论 5.1** 设  $X = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ ,  $\boldsymbol{\Sigma} = \begin{pmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{21} & \boldsymbol{\Sigma}_{22} \end{pmatrix}$ , 则  $X_1$  与  $X_2$  相互独立的充分必要条件是  $\boldsymbol{\Sigma}_{12} = \mathbf{0}$ .

**推论 5.2** 设  $X \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , 对于给定的矩阵  $\mathcal{A}$  与  $\mathcal{B}$ , 则  $\mathcal{A}X$  与  $\mathcal{B}X$  相互独立的充分必要条件是  $\mathcal{A}\boldsymbol{\Sigma}\mathcal{B}^T = \mathbf{0}$ .

**定理 5.2** 设  $X \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , 矩阵  $\mathcal{A}_{q \times p}$ , 向量  $\mathbf{c} \in \mathbb{R}^q$ , 且  $q \leq p$ , 则  $Y = \mathcal{A}X + \mathbf{c}$  服从  $q$  维正态分布, 即

$$Y \sim N_q(\mathcal{A}\boldsymbol{\mu} + \mathbf{c}, \mathcal{A}\boldsymbol{\Sigma}\mathcal{A}^T).$$

## 多元正态分布的基本性质

**定理 5.3** 给定  $X_1 = \mathbf{x}_1$  时  $X_2$  的条件分布亦是正态分布，其均值向量为

$\boldsymbol{\mu}_2 + \boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}(\mathbf{x}_1 - \boldsymbol{\mu}_1)$ ，协方差矩阵为  $\boldsymbol{\Sigma}_{22\cdot 1}$ ，即

$$(X_2 | X_1 = \mathbf{x}_1) \sim N_{p-r} \left( \boldsymbol{\mu}_2 + \boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}(\mathbf{x}_1 - \boldsymbol{\mu}_1), \boldsymbol{\Sigma}_{22\cdot 1} \right)$$

**证明：**  $X_{2\cdot 1} = X_2 - \boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}X_1 \implies X_2 = X_{2\cdot 1} + \boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}X_1$

对于给定  $X_1 = \mathbf{x}_1$  的值，

$$(X_2 | X_1 = \mathbf{x}_1) = X_{2\cdot 1} + \boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}\mathbf{x}_1$$

$$X_{2\cdot 1} \sim N_{p-r}(\boldsymbol{\mu}_{2\cdot 1}, \boldsymbol{\Sigma}_{22\cdot 1}) \implies (X_2 | X_1 = \mathbf{x}_1) \sim N(\boldsymbol{\mu}_2 + \boldsymbol{\Sigma}_{21}\boldsymbol{\Sigma}_{11}^{-1}\mathbf{x}_1, \boldsymbol{\Sigma}_{22\cdot 1})$$

$X_1$  的一个线性组合

与  $X_1$  无关

## 多元正态分布的基本性质

- 例: 设

$$p = 2, r = 1, \boldsymbol{\mu} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \boldsymbol{\Sigma} = \begin{pmatrix} 1 & -0.8 \\ -0.8 & 2 \end{pmatrix}$$

则

$$\begin{aligned} \Sigma_{11} &= 1, \quad \Sigma_{21} = -0.8, \\ \Sigma_{22 \cdot 1} &= \Sigma_{22} - \Sigma_{21} \Sigma_{11}^{-1} \Sigma_{12} = 2 - (-0.8) \times 1 \times (-0.8) = 1.36 \end{aligned}$$

定理 5.3 给定  $X_1 = x_1$  时  $X_2$  的条件分布亦是正态分布, 其均值向量为  $\boldsymbol{\mu}_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \boldsymbol{\mu}_1)$ , 协方差矩阵为  $\Sigma_{22 \cdot 1}$ , 即  $(X_2 | X_1 = x_1) \sim N_{p-r}(\boldsymbol{\mu}_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \boldsymbol{\mu}_1), \Sigma_{22 \cdot 1})$

$X_1$  的边际概率密度函数为

$$f_{X_1}(x_1) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x_1^2}{2}\right)$$

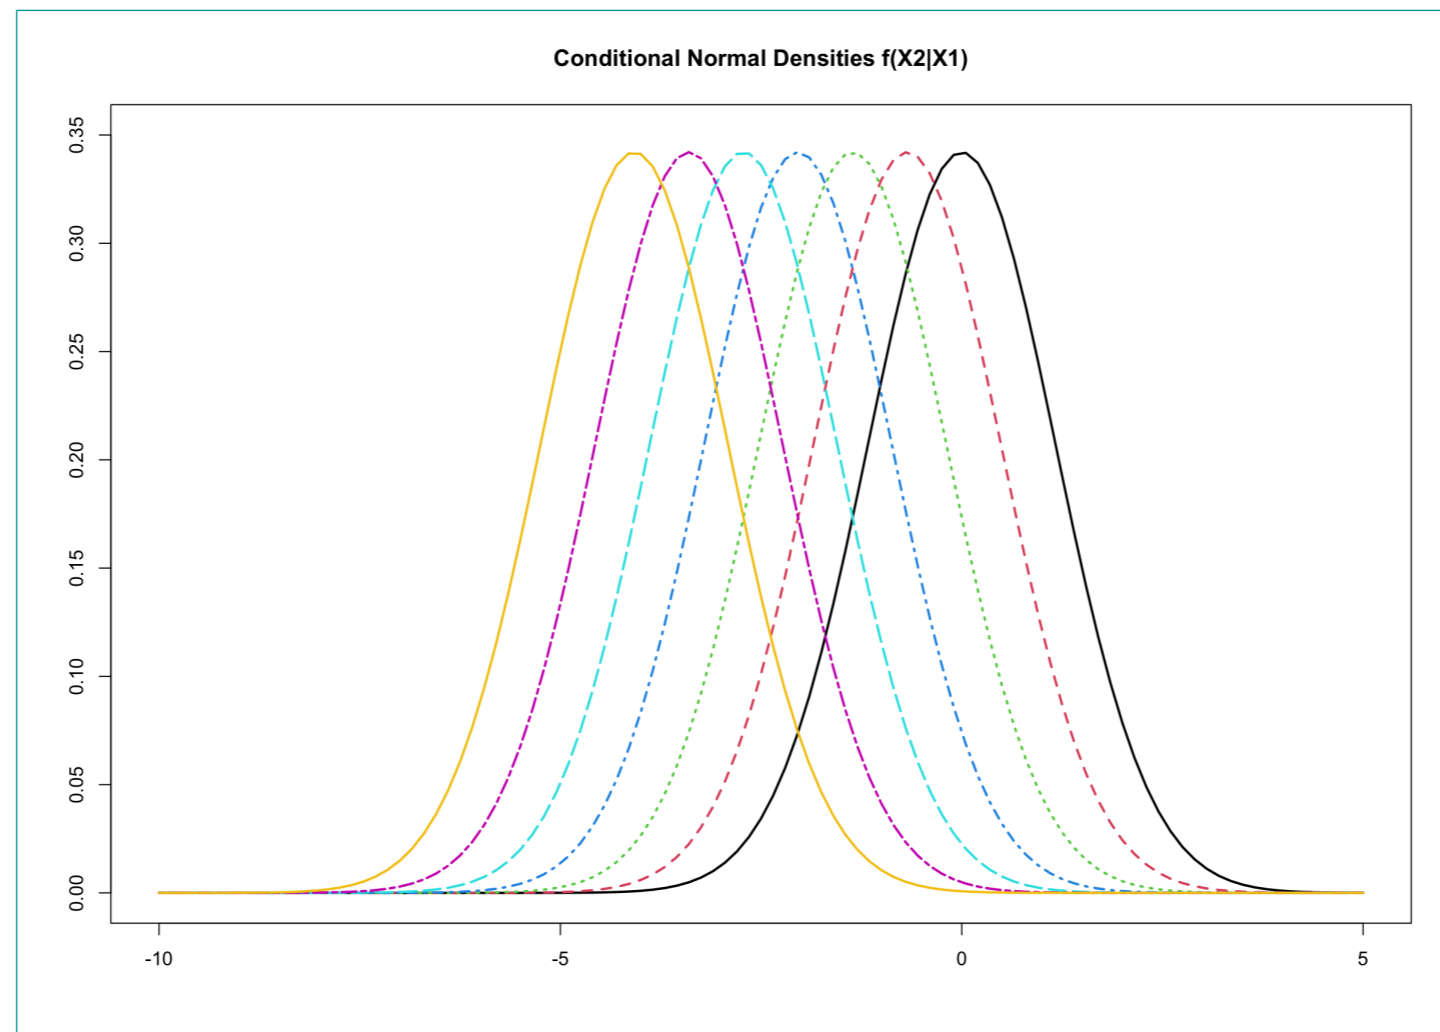
$(X_2 | X_1 = x_1)$  的条件概率密度函数为

$$f(x_2 | x_1) = \frac{1}{\sqrt{2\pi \times (1.36)}} \exp\left(-\frac{(x_2 + 0.8x_1)^2}{2 \times (1.36)}\right)$$

条件均值  $E(X_2 | X_1 = x_1) = -0.8x_1$   
 是  $X_1$  的线性函数.

## 多元正态分布的基本性质

```
x = 0
mu = -0.8 * x
sigma = sqrt(1.36)
curve(dnorm(x, mu, sigma), -10, 5, col=1, xlab="", ylab="", lwd=2, ylim=c(0, 0.35),
      main='Conditional Normal Densities f(X2|X1)')
for (i in 1:6) {
  x = x + 0.85
  mu = -0.8 * x
  curve(dnorm(x, mu, sigma), -10, 5, col=i+1, xlab="", ylab="", add=TRUE, lty=i+1, lwd=2)
}
```



## 多元正态分布的基本性质

**定理 5.4** 设  $X_1 \sim N_r(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_{11})$ ,  $(X_2 | X_1 = \mathbf{x}_1) \sim N_{p-r}(\mathcal{A}\mathbf{x}_1 + \mathbf{b}, \boldsymbol{\Omega})$ , 其中  $\boldsymbol{\Omega}$  不依赖于  $\mathbf{x}_1$ , 则

$$\mathbf{X} = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$$

其中

$$\boldsymbol{\mu} = \begin{pmatrix} \boldsymbol{\mu}_1 \\ \mathcal{A}\boldsymbol{\mu}_1 + \mathbf{b} \end{pmatrix}, \quad \boldsymbol{\Sigma} = \begin{pmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{11}\mathcal{A}^T \\ \mathcal{A}\boldsymbol{\Sigma}_{11} & \boldsymbol{\Omega} + \boldsymbol{\Sigma}_{11}\mathcal{A}^T \end{pmatrix}$$

## 多元正态分布的基本性质

- 例：考虑下述随机变量

$$X_1 \sim N_1(0, 1), \quad (X_2 | X_1 = x_1) \sim N_2 \left( \begin{pmatrix} 2x_1 \\ x_1 + 1 \end{pmatrix}, \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right)$$

$$\mathcal{A} = \begin{pmatrix} 2 \\ 1 \end{pmatrix}, \quad \mathbf{b} = \begin{pmatrix} 0 \\ 1 \end{pmatrix}, \quad \Omega = \mathcal{I}_2$$

$$\mathbf{X} = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} \sim N_3 \left( \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}, \begin{pmatrix} 1 & 2 & 1 \\ 2 & 5 & 2 \\ 1 & 2 & 2 \end{pmatrix} \right)$$

$$\Rightarrow X_2 \sim N_2 \left( \begin{pmatrix} 0 \\ 1 \end{pmatrix}, \begin{pmatrix} 5 & 2 \\ 2 & 2 \end{pmatrix} \right)$$

定理 5.4 设  $X_1 \sim N_r(\mu_1, \Sigma_{11})$ ,  $(X_2 | X_1 = x_1) \sim N_{p-r}(\mathcal{A}x_1 + \mathbf{b}, \Omega)$ , 其中  $\Omega$  不依赖于  $x_1$ , 则

$$\mathbf{X} = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix} \sim N_p(\boldsymbol{\mu}, \Sigma)$$

其中

$$\boldsymbol{\mu} = \begin{pmatrix} \mu_1 \\ \mathcal{A}\mu_1 + \mathbf{b} \end{pmatrix}, \quad \Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{11}\mathcal{A}^T \\ \mathcal{A}\Sigma_{11} & \Omega + \Sigma_{11}\mathcal{A}^T \end{pmatrix}$$

- ▶ 在  $X_1$  给定的条件下,  $X_2$  的两个分量相互独立.
- ▶ 但从  $X_2$  的边缘分布来看, 它的两个分量不相互独立.

## 多元正态分布的基本性质

- 例：考虑下述随机变量

$$X_1 \sim N_1(0, 1), \quad (\mathbf{X}_2 | X_1 = x_1) \sim N_2 \left( \begin{pmatrix} 2x_1 \\ x_1 + 1 \end{pmatrix}, \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right)$$

- ▶  $\mathbf{X}_2$  的边际分布的均值向量与协方差矩阵可计算如下

$$E(\mathbf{X}_2) = E \left[ E(\mathbf{X}_2 | X_1) \right] = E \left[ \begin{pmatrix} 2X_1 \\ X_1 + 1 \end{pmatrix} \right] = \begin{pmatrix} E(2X_1) \\ E(X_1) + 1 \end{pmatrix} = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

$$\text{Var}(\mathbf{X}_2) = E \left[ \text{Var}(\mathbf{X}_2 | X_1) \right] + \text{Var} \left[ E(\mathbf{X}_2 | X_1) \right]$$

$$= E \left[ \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right] + \text{Var} \left[ \begin{pmatrix} 2X_1 \\ X_1 + 1 \end{pmatrix} \right]$$

$$= \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \begin{pmatrix} 4 & 2 \\ 2 & 1 \end{pmatrix} = \begin{pmatrix} 5 & 2 \\ 2 & 2 \end{pmatrix}$$

# 多元正态分布的基本性质

- 条件逼近

定理 4.3 设  $X_1 \in \mathbb{R}^k$ ,  $X_2 \in \mathbb{R}^{p-k}$ ,  $U = X_2 - E(X_2 | X_1)$ . 则

- $E(U) = \mathbf{0}$ .
- 用  $X_1$  的一个函数  $h(X_1)$  对  $X_2$  作近似, 则  $E(X_2 | X_1)$  是一个“最佳”逼近, 其中  $h: \mathbb{R}^k \rightarrow \mathbb{R}^{p-k}$ . 所谓“最佳”是指均方误差 (MSE) 最小的意义下, 其中

$$\text{MSE}(h) = E \left\{ \left[ X_2 - h(X_1) \right]^T \left[ X_2 - h(X_1) \right] \right\}.$$

$$\Rightarrow X_2 = E(X_2 | X_1) + U$$

$$= \mu_2 + \Sigma_{21} \Sigma_{11}^{-1} (X_1 - \mu_1) + U$$

$$= \beta_0 + \Sigma_{21} \Sigma_{11}^{-1} \mu_1 + \Sigma_{21} \Sigma_{11}^{-1} X_1 + U$$

$$= \beta_0 + \mathcal{B} X_1 + U$$

$$\rightarrow N(\mathbf{0}, \Sigma_{22.1})$$

定理 5.3 给定  $X_1 = x_1$  时  $X_2$  的条件分布亦是正态分布, 其均值向量为  $\mu_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \mu_1)$ , 协方差矩阵为  $\Sigma_{22.1}$ , 即  
 $(X_2 | X_1 = x_1) \sim N_{p-r}(\mu_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \mu_1), \Sigma_{22.1})$

# 多元正态分布的基本性质

- 条件逼近

$$X_2 = \beta_0 + \mathcal{B}X_1 + U$$

$\beta_0 = \mu_2 - \mathcal{B}\mu_1$        $\mathcal{B} = \Sigma_{21}\Sigma_{11}^{-1}$        $U \sim N(\mathbf{0}, \Sigma_{22.1})$

▶ 一种特殊情形:  $X = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix}_{p \times 1}$ ,  $X_2 \in \mathbb{R}$

$$\beta_0 = \mu_2 - \beta^T \mu_1 \implies X_2 = \beta_0 + \beta^T X_1 + U$$

$\beta^T = \mathcal{B} = (\sigma_{21})_{1 \times (p-1)} (\Sigma_{11}^{-1})_{(p-1) \times (p-1)}$        $U \sim N(0, \sigma_{22.1})$

▶ 用  $X_1$  的一个函数对  $X_2$  的最佳 MSE 逼近是一个超平面.

▶  $X_2$  的边际分布的方差为

$$\sigma_{22} = \beta^T \Sigma_{11} \beta + \sigma_{22.1} = \sigma_{21} \Sigma_{11}^{-1} \Sigma_{11} \Sigma_{11}^{-1} \sigma_{12} + \sigma_{22.1} = \sigma_{21} \Sigma_{11}^{-1} \sigma_{12} + \sigma_{22.1}$$

$$\implies \frac{\sigma_{21} \Sigma_{11}^{-1} \sigma_{12}}{\sigma_{22}} + \frac{\sigma_{22.1}}{\sigma_{22}} = 1$$

## 多元正态分布的基本性质

- 条件逼近

$$\frac{\sigma_{21} \Sigma_{11}^{-1} \sigma_{12}}{\sigma_{22}} + \frac{\sigma_{22 \cdot 1}}{\sigma_{22}} = 1$$

- ▶  $\rho_{2 \cdot 1 \dots (p-1)}^2$ :  $X_2$  与  $r$  个变量  $X_1$  之间的多重相关系数的平方.
- ▶  $\rho_{2 \cdot 1 \dots (p-1)}^2$ :  $X_2$  的方差可以由线性逼近  $\beta_0 + \beta^T X_1$  进行解释的比例.
- ▶  $\rho_{2 \cdot 1 \dots (p-1)}^2$ :  $X_2$  与  $X_1$  分量的线性组合之间的相关系数能够达到的最大值.
- ▶  $\rho_{2 \cdot 1 \dots (p-1)}^2$ : 当  $p = 2$  时, 多重相关系数  $\rho_{21}$  和  $X_2$  与  $X_1$  常规的简单相关系数恰好相同.

# 多元正态分布的基本性质

- 例：考虑“经典蓝”套头衫数据集，设  $X_1$  (销量)、 $X_2$  (价格)、 $X_3$  (广告费用) 和  $X_4$  (促销员费用) 服

从正态分布，其中

$$\mu = \begin{pmatrix} 172.7 \\ 104.6 \\ 104.0 \\ 93.8 \end{pmatrix}, \quad \Sigma = \begin{pmatrix} 1037.21 & -80.02 & 1430.7 & 271.44 \\ -80.02 & 219.84 & 92.1 & -91.58 \\ 1430.70 & 92.10 & 2624.0 & 210.30 \\ 271.44 & -91.58 & 210.3 & 177.36 \end{pmatrix}$$

```

> pullover
      X1  X2  X3  X4
1  230 125 200 109
2  181  99  55 107
3  165  97 105  98
4  150 115  85  71
5   97 120   0  82
6  192 100 150 103
7  181  80  85 111
8  189  90 120  93
9  172  95 110  86
10 170 125 130  78
  
```

```

x <- c(230, 125, 200, 109, 181, 99, 55, 107, 165, 97, 105, 98, 150, 115, 85, 71, 97, 120, 0, 82,
      192, 100, 150, 103, 181, 80, 85, 111, 189, 90, 120, 93, 172, 95, 110, 86, 170, 125, 130, 78)
pullover <- matrix(x, ncol = 4, byrow = TRUE)
pullover <- as.data.frame(pullover)
colnames(pullover) <- c("X1", "X2", "X3", "X4")
pullover
mu = apply(pullover, 2, mean)
mu
Sigma = var(pullover) * (9 / 10)
Sigma
  
```

```

> apply(pullover, 2, mean)
      X1  X2  X3  X4
172.7 104.6 104.0 93.8
  
```

```

> var(pullover) * (9 / 10)
      X1  X2  X3  X4
X1 1037.21 -80.02 1430.7 271.44
X2 -80.02 219.84  92.1 -91.58
X3 1430.70  92.10 2624.0 210.30
X4 271.44 -91.58  210.3 177.36
  
```

# 多元正态分布的基本性质

- 例：**考虑“经典蓝”套头衫数据集，设  $X_1$  (销量)、 $X_2$  (价格)、 $X_3$  (广告费用) 和  $X_4$  (促销员费用) 服从正态分布，其中

$$\mu = \begin{pmatrix} 172.7 \\ 104.6 \\ 104.0 \\ 93.8 \end{pmatrix} \begin{matrix} \mu_1 \\ \mu_2 \\ \mu_3 \\ \mu_4 \end{matrix}, \quad \Sigma = \begin{pmatrix} \overset{\sigma_{11}}{1037.21} & -80.02 & 1430.7 & 271.44 \\ -80.02 & 219.84 & 92.1 & -91.58 \\ 1430.70 & 92.10 & \underset{\Sigma_{22}}{2624.0} & 210.30 \\ 271.44 & -91.58 & 210.3 & 177.36 \end{pmatrix} \begin{matrix} \sigma_{12} \\ \sigma_{21} \end{matrix}$$

- 则给定  $(X_2, X_3, X_4)$  时  $X_1$  的条件分布服从一元正态分布，其均值为

$$\mu_1 + \sigma_{12} \Sigma_{22}^{-1} \begin{pmatrix} X_2 - \mu_2 \\ X_3 - \mu_3 \\ X_4 - \mu_4 \end{pmatrix}$$

定理 5.3 给定  $X_1 = x_1$  时  $X_2$  的条件分布亦是正态分布，其均值向量为  $\mu_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \mu_1)$ ，协方差矩阵为  $\Sigma_{22.1}$ ，即  $(X_2 | X_1 = x_1) \sim N_{p-r}(\mu_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \mu_1), \Sigma_{22.1})$

$$\begin{aligned}
 &= 172.7 + (-80.02 \quad 1430.70 \quad 271.44) \begin{pmatrix} 219.84 & 92.10 & -91.58 \\ 92.10 & 2624.00 & 210.30 \\ -91.58 & 210.30 & 177.36 \end{pmatrix}^{-1} \begin{pmatrix} X_2 - 104.6 \\ X_3 - 104.0 \\ X_4 - 93.8 \end{pmatrix} \\
 &= 65.670 - 0.216X_2 + 0.485X_3 + 0.844X_4
 \end{aligned}$$

# 多元正态分布的基本性质

- 例：**考虑“经典蓝”套头衫数据集，设  $X_1$  (销量)、 $X_2$  (价格)、 $X_3$  (广告费用) 和  $X_4$  (促销员费用) 服从正态分布，其中

$$\mu = \begin{pmatrix} 172.7 \\ 104.6 \\ 104.0 \\ 93.8 \end{pmatrix} \begin{matrix} \mu_1 \\ \mu_2 \\ \mu_3 \\ \mu_4 \end{matrix}, \quad \Sigma = \begin{pmatrix} \overset{\sigma_{11}}{1037.21} & -80.02 & \overset{\sigma_{12}}{1430.7} & 271.44 \\ -80.02 & 219.84 & 92.1 & -91.58 \\ 1430.70 & 92.10 & 2624.0 & 210.30 \\ \underset{\sigma_{21}}{271.44} & \underset{\Sigma_{22}}{-91.58} & 210.3 & 177.36 \end{pmatrix}$$

- 则给定  $(X_2, X_3, X_4)$  时  $X_1$  的条件分布服从一元正态分布，其均值为

```

mu_2 = as.matrix(mu[2:4])
Sigma_21 = as.matrix(Sigma[1, 2:4])
Sigma_22 = as.matrix(Sigma[2:4, 2:4])
t(Sigma_21) %*% solve(Sigma_22)
mu[1] - t(Sigma_21) %*% solve(Sigma_22) %*% mu_2
    
```

```

> t(Sigma_21) %*% solve(Sigma_22)
           X2           X3           X4
[1,] -0.2157821  0.4851898  0.8437261
> mu[1] - t(Sigma_21) %*% solve(Sigma_22) %*% mu_2
           [,1]
[1,] 65.66956
    
```

$$= 65.670 - 0.216X_2 + 0.485X_3 + 0.844X_4$$

# 多元正态分布的基本性质

- 例：**考虑“经典蓝”套头衫数据集，设  $X_1$  (销量)、 $X_2$  (价格)、 $X_3$  (广告费用) 和  $X_4$  (促销员费用) 服从正态分布，其中

$$\mu = \begin{pmatrix} 172.7 \\ 104.6 \\ 104.0 \\ 93.8 \end{pmatrix} \begin{matrix} \mu_1 \\ \mu_2 \\ \mu_3 \\ \mu_4 \end{matrix}, \quad \Sigma = \begin{pmatrix} \overset{\sigma_{11}}{1037.21} & -80.02 & 1430.7 & 271.44 \\ -80.02 & 219.84 & 92.1 & -91.58 \\ 1430.70 & 92.10 & \underset{\Sigma_{22}}{2624.0} & 210.30 \\ 271.44 & -91.58 & 210.3 & 177.36 \end{pmatrix} \begin{matrix} \sigma_{12} \\ \sigma_{21} \end{matrix}$$

- 则给定  $(X_2, X_3, X_4)$  时  $X_1$  的条件分布服从一元正态分布，其方差为

$$\sigma_{11.2} = \sigma_{11} - \sigma_{12} \Sigma_{22}^{-1} \sigma_{21}$$

定理 5.3 给定  $X_1 = x_1$  时  $X_2$  的条件分布亦是正态分布，其均值向量为  $\mu_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \mu_1)$ ，协方差矩阵为  $\Sigma_{22.1}$ ，即  $(X_2 | X_1 = x_1) \sim N_{p-r}(\mu_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \mu_1), \Sigma_{22.1})$

$$= 1037.21 - (-80.02 \quad 1430.70 \quad 271.44) \begin{pmatrix} 219.84 & 92.10 & -91.58 \\ 92.10 & 2624.00 & 210.30 \\ -91.58 & 210.30 & 177.36 \end{pmatrix}^{-1} \begin{pmatrix} -80.02 \\ 1430.70 \\ 271.44 \end{pmatrix} = 96.761$$

```
Sigma[1, 1] - t(Sigma_21) %*% solve(Sigma_22) %*% Sigma_12
```

```
> Sigma[1, 1] - t(Sigma_21) %*% solve(Sigma_22) %*% Sigma_21
      [,1]
[1,] 96.76111
```

## 多元正态分布的基本性质

- 例：考虑“经典蓝”套头衫数据集，设  $X_1$  (销量)、 $X_2$  (价格)、 $X_3$  (广告费用) 和  $X_4$  (促销员费用) 服从正态分布，其中

$$\mu = \begin{pmatrix} 172.7 \\ 104.6 \\ 104.0 \\ 93.8 \end{pmatrix} \begin{matrix} \mu_1 \\ \mu_2 \\ \mu_3 \\ \mu_4 \end{matrix} \quad \Sigma = \begin{pmatrix} \overset{\sigma_{11}}{1037.21} & -80.02 & \overset{\sigma_{12}}{1430.7} & 271.44 \\ -80.02 & 219.84 & 92.1 & -91.58 \\ 1430.70 & 92.10 & \underset{\Sigma_{22}}{2624.0} & 210.30 \\ 271.44 & -91.58 & 210.3 & 177.36 \end{pmatrix} \begin{matrix} \sigma_{21} \\ \sigma_{22} \end{matrix}$$

- 价格 ( $X_2$ )、广告费用 ( $X_3$ ) 和促销员费用 ( $X_4$ ) 对销售量 ( $X_1$ ) 的线性逼近由条件均值给出

$$65.670 - 0.216 X_2 + 0.485 X_3 + 0.844 X_4$$

- 逼近的效果由多重相关系数给出

$$\rho_{1.234}^2 = \frac{\sigma_{12} \Sigma_{22}^{-1} \sigma_{21}}{\sigma_{11}} = 0.907$$

```
t(Sigma_21) %*% solve(Sigma_22) %*% Sigma_21 / Sigma[1, 1]
```

```
> t(Sigma_21) %*% solve(Sigma_22) %*% Sigma_21 / Sigma[1, 1]
      [,1]
[1,] 0.9067102
```

# 多元正态分布的基本性质

- 例：考虑“经典蓝”套头衫数据集，设  $X_1$  (销量)、 $X_2$  (价格)、 $X_3$  (广告费用) 和  $X_4$  (促销员费用) 服从

正态分布，其中

$$\mu = \begin{pmatrix} 172.7 \\ 104.6 \\ 104.0 \\ 93.8 \end{pmatrix}, \quad \Sigma = \begin{pmatrix} 1037.21 & -80.02 & 1430.7 & 271.44 \\ -80.02 & 219.84 & 92.1 & -91.58 \\ 1430.70 & 92.10 & 2624.0 & 210.30 \\ 271.44 & -91.58 & 210.3 & 177.36 \end{pmatrix}$$

$\Sigma_{11}$                        $\Sigma_{12}$   
 $\Sigma_{21}$                        $\Sigma_{22}$

- 给定  $(X_3, X_4)$  时， $(X_1, X_2)$  的条件分布为二元正态分布，均值向量为

$$\mu_1 + \Sigma_{12} \Sigma_{22}^{-1} (x_2 - \mu_2)$$

定理 5.3 给定  $X_1 = x_1$  时  $X_2$  的条件分布亦是正态分布，其均值向量为  $\mu_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \mu_1)$ ，协方差矩阵为  $\Sigma_{22.1}$ ，即  $(X_2 | X_1 = x_1) \sim N_{p-r}(\mu_2 + \Sigma_{21} \Sigma_{11}^{-1} (x_1 - \mu_1), \Sigma_{22.1})$

$$= \begin{pmatrix} 172.7 \\ 104.6 \end{pmatrix} + \begin{pmatrix} 1430.70 & 271.44 \\ 92.10 & -91.58 \end{pmatrix} \begin{pmatrix} 2624.00 & 210.30 \\ 210.30 & 177.36 \end{pmatrix}^{-1} \begin{pmatrix} X_3 - 104.0 \\ X_4 - 93.8 \end{pmatrix} = \begin{pmatrix} 32.516 + 0.467X_3 + 0.977X_4 \\ 153.644 + 0.085X_3 - 0.617X_4 \end{pmatrix}$$

```
mu_1 = as.matrix(mu[1:2])
mu_2 = as.matrix(mu[3:4])
Sigma_11 = as.matrix(Sigma[1:2, 1:2])
Sigma_12 = as.matrix(Sigma[1:2, 3:4])
Sigma_21 = as.matrix(Sigma[3:4, 1:2])
Sigma_22 = as.matrix(Sigma[3:4, 3:4])
Sigma_12 %*% solve(Sigma_22)
mu_1 - Sigma_12 %*% solve(Sigma_22) %*% mu_2
```

```
> Sigma_12 %*% solve(Sigma_22)
      X3      X4
X1 0.46695332 0.9767688
X2 0.08451319 -0.6165602
> mu_1 - Sigma_12 %*% solve(Sigma_22) %*% mu_2
      [,1]
X1 32.51594
X2 153.64398
```





## 多元正态分布的基本性质

- 例：考虑“经典蓝”套头衫数据集。
  - ▶ 4 个变量的相关矩阵为

$$P = \begin{pmatrix} 1 & -0.168 & 0.867 & 0.633 \\ -0.168 & 1 & 0.121 & -0.464 \\ 0.867 & 0.121 & 1 & 0.308 \\ 0.633 & -0.464 & 0.308 & 1 \end{pmatrix}$$

```
> cor(pullover)
      X1      X2      X3      X4
X1  1.0000000 -0.1675760 0.8672280 0.6328673
X2 -0.1675760 1.0000000 0.1212619 -0.4637879
X3  0.8672280  0.1212619 1.0000000 0.3082688
X4  0.6328673 -0.4637879 0.3082688 1.0000000
```

cor(pullover)

$$\Rightarrow \rho_{X_1 X_2} = -0.168$$

$$\Rightarrow \rho_{X_1 X_2 | X_3 X_4} = -0.264$$

# Wishart 分布

数据矩阵:  $\mathcal{X} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} = \begin{pmatrix} \mathbf{x}_1^T \\ \mathbf{x}_2^T \\ \vdots \\ \mathbf{x}_n^T \end{pmatrix}.$

均值向量:  $\bar{\mathbf{x}} = n^{-1} \mathcal{X}^T \mathbf{1}_n$

$\mathbf{1}_n = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix}_{n \times 1}$

样本协方差矩阵:  $\mathcal{S} = \frac{1}{n} \sum_{k=1}^n (\mathbf{x}_k - \bar{\mathbf{x}}) (\mathbf{x}_k - \bar{\mathbf{x}})^T$

$= \frac{1}{n} \mathcal{X}^T \mathcal{X} - \bar{\mathbf{x}} \bar{\mathbf{x}}^T$

$= \frac{1}{n} \mathcal{X}^T \mathcal{H} \mathcal{X}$

中心化矩阵:  $\mathcal{H} = \mathcal{I}_n - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n^T$

- Wishart 分布在估计协方差矩阵的分析中发挥着重要作用.

## Wishart 分布

定义 5.1 随机矩阵  $\mathcal{X} = (X_{ij})_{m \times n}$  的分布是指其所有元素构成的随机向量

$$\mathbf{X} = (X_{11}, \dots, X_{1n}, X_{21}, \dots, X_{2n}, \dots, X_{m1}, \dots, X_{mn})$$

的联合分布.

- ▶ 当  $m = n$  且  $\mathcal{X} = (X_{ij})_{n \times n}$  为对称矩阵时, 我们只需考虑其下三角矩阵的元素

$$\mathcal{X} = \begin{pmatrix} X_{11} & & & \\ X_{21} & X_{22} & & \\ \vdots & \vdots & \ddots & \\ X_{n1} & X_{n2} & \cdots & X_{nn} \end{pmatrix}_{n \times n}$$

即,  $\mathbf{X} = (X_{11}, X_{21}, \dots, X_{n1}, X_{22}, \dots, X_{n2}, \dots, X_{nn})$  的分布.

# Wishart 分布

- 数据矩阵  $\mathcal{X} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} = \begin{pmatrix} \mathbf{x}_1^T \\ \mathbf{x}_2^T \\ \vdots \\ \mathbf{x}_n^T \end{pmatrix}$ .
- 假设  $\mathbf{x}_i = \begin{pmatrix} x_{i1} \\ x_{i2} \\ \vdots \\ x_{ip} \end{pmatrix} \stackrel{\text{i.i.d.}}{\sim} N_p(\boldsymbol{\mu}_i, \boldsymbol{\Sigma})$ ,  $i = 1, 2, \dots, n$ 
  
 $\boldsymbol{\mu}_i = \begin{pmatrix} \mu_{i1} \\ \mu_{i2} \\ \vdots \\ \mu_{ip} \end{pmatrix}, i = 1, 2, \dots, n$
- 记  $\mathcal{M} = \mathbb{E}(\mathcal{X}) = \begin{pmatrix} \mu_{11} & \mu_{12} & \cdots & \mu_{1p} \\ \mu_{21} & \mu_{22} & \cdots & \mu_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \mu_{n1} & \mu_{n2} & \cdots & \mu_{np} \end{pmatrix} = \begin{pmatrix} \boldsymbol{\mu}_1^T \\ \boldsymbol{\mu}_2^T \\ \vdots \\ \boldsymbol{\mu}_n^T \end{pmatrix}$

**定义 5.2** 设  $\mathcal{A} = \mathcal{X}^T \mathcal{X} = \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T$ ,  
 则称  $\mathcal{A}$  服从非中心 Wishart 分布  
 $W_p(\boldsymbol{\Sigma}, n, \boldsymbol{\tau})$ , 其中  $\boldsymbol{\tau} = \mathcal{M}^T \mathcal{M}$  是非  
 中心参数.

- ▶ 当  $\boldsymbol{\mu}_i = \mathbf{0}, i = 1, 2, \dots, n$  时, 有  $\boldsymbol{\tau} = \mathbf{0}$ , 则称  $\mathcal{A}$  服从中心 Wishart 分布, 记作  $\mathcal{A} \sim W_p(\boldsymbol{\Sigma}, n)$ .

## Wishart 分布

- 例：取  $p = 1$ ，则对  $X \sim N_1(0, \sigma^2)$ ，数据矩阵为

$$\begin{aligned} \mathcal{X} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} &\Rightarrow \mathcal{A} = \mathcal{X}^T \mathcal{X} = (x_1 \ x_2 \ \cdots \ x_n) \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = \sum_{i=1}^n x_i^2 \\ &= \sigma^2 \sum_{i=1}^n \left[ \left( \frac{x_i}{\sigma} \right)^2 \right] \\ &= \sigma^2 \cdot \chi_n^2 \end{aligned}$$

## Wishart 分布

**定理 5.5** 如果  $\mathcal{A} \sim W_p(\Sigma, n)$ , 矩阵  $\mathcal{B}_{p \times q}$ , 则  $\mathcal{B}^T \mathcal{A} \mathcal{B}$  服从 Wishart 分布  $W_q(\mathcal{B}^T \Sigma \mathcal{B}, n)$ .

$\mathcal{A}$  的线性变换

▶ 若取  $\mathcal{B} = \Sigma^{-1/2}$ , 则  $\Sigma^{-1/2} \mathcal{A} \Sigma^{-1/2}$  即服从标准 Wishart 分布  $W_p(\mathcal{I}, n)$ .

**定理 5.6** 设  $\mathcal{A} \sim W_p(\Sigma, m)$ ,  $\mathbf{a} \in \mathbb{R}^p$  满足  $\mathbf{a}^T \Sigma \mathbf{a} \neq 0$ , 则  $\frac{\mathbf{a}^T \mathcal{A} \mathbf{a}}{\mathbf{a}^T \Sigma \mathbf{a}}$  服从  $\chi_m^2$  分布.

$$\mathbf{x}_i \stackrel{\text{i.i.d.}}{\sim} N_p(\mathbf{0}, \Sigma) \implies \mathcal{A} = \mathcal{X}^T \mathcal{X} = \sum_{i=1}^m \mathbf{x}_i \mathbf{x}_i^T \sim W_p(\Sigma, m)$$

$$\implies \mathbf{a}^T \mathbf{x}_i \sim N_1(\mathbf{0}, \mathbf{a}^T \Sigma \mathbf{a})$$

$$\implies \frac{\mathbf{a}^T \mathbf{x}_i}{(\mathbf{a}^T \Sigma \mathbf{a})^{1/2}} \sim N_1(\mathbf{0}, 1) \implies \frac{\mathbf{a}^T \mathcal{A} \mathbf{a}}{\mathbf{a}^T \Sigma \mathbf{a}} = \sum_{i=1}^m \left[ \frac{\mathbf{a}^T \mathbf{x}_i}{(\mathbf{a}^T \Sigma \mathbf{a})^{1/2}} \cdot \frac{\mathbf{x}_i^T \mathbf{a}}{(\mathbf{a}^T \Sigma \mathbf{a})^{1/2}} \right] \sim \chi_m^2$$

## Wishart 分布

**定理 5.7 (Cochran)** 设  $\mathcal{X}_{n \times p}$  是来自正态分布  $N_p(\mathbf{0}, \Sigma)$  的一个数据矩阵, 设  $\mathcal{C}_{n \times n}$  是一个对称矩阵. 则

(a)  $\mathcal{X}^T \mathcal{C} \mathcal{X}$  服从加权 Wishart 随机变量和的分布, 即

$$\mathcal{X}^T \mathcal{C} \mathcal{X} = \sum_{i=1}^n \lambda_i W_p(\Sigma, 1)$$

其中  $\lambda_i$  ( $i = 1, 2, \dots, n$ ) 是  $\mathcal{C}$  的特征值.

(b)  $\mathcal{X}^T \mathcal{C} \mathcal{X}$  服从 Wishart 分布的充分必要条件是  $\mathcal{C}^2 = \mathcal{C}$ . 此时有

$$\mathcal{X}^T \mathcal{C} \mathcal{X} \sim W_p(\Sigma, r)$$

其中  $r = \text{rank}(\mathcal{C}) = \text{tr}(\mathcal{C})$ .

(c)  $n\mathcal{S} = \mathcal{X}^T \mathcal{H} \mathcal{X}$  服从 Wishart 分布  $W_p(\Sigma, n - 1)$ .

$$\mathcal{H} = \mathcal{I}_n - \frac{1}{n} \mathbf{1}_n \mathbf{1}_n^T$$

(d)  $\bar{\mathbf{x}}$  与  $\mathcal{S}$  相互独立.

$$\mathcal{S} = \frac{1}{n} \mathcal{X}^T \mathcal{H} \mathcal{X}$$